acs
applied computer science

UNIVERZITET U NOVOM SADU
FAKULTET TEHNIČKIH NAUKA
KATEDRA ZA PRIMENJENE RAČUNARSKE NAUKE

DAIS
Data Science and
Information Systems Group

Rasuta organizacija datoteke

Struktura, formiranje, traženje, obrada, ažuriranje, primena i ocena

Baze podataka 1 - Informacioni inženjering

Sadržaj

- Rasute organizacije datoteka
- Direktna i relativna organizacija datoteke
- Statička rasuta organizacija datoteke
- Dinamička rasuta organizacija datoteke

Rasute organizacije datoteka

- **Rasuta organizacija datoteke**
  - često se, u najširem značenju, naziva i direktnom jer se
    - slogu ili grupi slogova pristupa direktno na osnovu poznavanja adrese memorijske lokacije u kojoj su smešteni
    - adresa lokacije dobija transformacijom vrednosti identifikatora sloga u adresu
  - **identifikator** – skup obeležja čije vrednosti jednoznačno određuju slogove datoteke
    - identifikator može a ne mora pripadati skupu obeležja tipa sloga datoteke – **interni** ili **eksterni**
    - **interni identifikator** - po pravilu, primarni ključ datoteke
    - **eksterni identifikator** - vrednosti identifikatora pidružuju se svakom slogu eksterno, van konteksta sadržaja datoteke

Rasute organizacije datoteka

- **Rasuta organizacija datoteke**
  - transformacija vrednosti identifikatora u adresu
    - h: $dom(K) \rightarrow A$
      - K - domen identifikatora
      - A - skup adresa lokacija memorijskog prostora datoteke
  - vrste transformacija vrednosti identifikatora u adresu
    - **deterministička**
      - funkcija h je injektivna
      - svakoj vrednosti identifikatora odgovara jedna adresa
      - svakoj adresi odgovara najviše jedna vrednost identifikatora
    - **probabilistička**
      - svakoj vrednosti identifikatora odgovara jedna adresa
      - jednoj adresi može odgovarati više rezultata transformacije
      - metoda za generisanje pseudoslučajnih brojeva

Rasute organizacije datoteka

- **Rasuta organizacija datoteke**
  - fizička struktura podataka ne sadrži informaciju o vezama između slogova logičke strukture datoteke
    - u dve fizički susedne lokacije mogu a ne moraju biti memorisani logički susedni slogovi
    - slogovi su, na slučajan način, rasuti po memorijskom prostoru datoteke
- **Baket**
  - tradicionalan naziv za blok kod rasutih datoteka
  - faktor baketiranja b ($b \geq 1$) = faktor blokiranja f
  - transformacijom h vrednost identifikatora pretvara se u adresu baketa

Rasute organizacije datoteka

- Primer - rasuta datoteka - D_{ras}
  - slogova $N = 10$
  - faktor baketiranja $b = 3$
  - datoteci je dodeljeno $B = 5$ baketa
  - identifikator
    - primarni ključ datoteke
  - transformacija
    - $h(k_i)=1+k(S_i) (\text{mod } B)$ $i \in \{1,\ldots,N\}$
    - rezultat : relativna adresa baketa iz skupa $\{1,2,3,4,5\}$

1						
	15	$p(S_4)$	25	$p(S_7)$		
2						
3						
	07	$p(S_2)$	27	$p(S_9)$		
4						
	03	$p(S_3)$	23	$p(S_8)$	13	$p(S_{10})$
5						
	34	$p(S_1)$	19	$p(S_5)$	29	$p(S_6)$

Rasute organizacije datoteka

- **Vrste rasutih datoteka**
  - s obzirom na način alokacije memorijskog prostora
  - **statičke**
    - veličina adresnog prostora određuje se i kompletno alocira unapred, statički
    - ne može se menjati tokom eksploatacije
  - **dinamičke**
    - veličina dodeljenog adresnog prostora menja se tokom ažuriranja, saglasno potrebama
  - istorijski gledano, statičke rasute datoteke nastale su znatno ranije od dinamičkih

Rasute organizacije datoteka

- **Opšti postupak formiranja statičke rasute**
  - statičkoj rasutoj datoteci, u postupku formiranja, dodeljuje se $Q = bB$ lokacija, $N \leq Q$
    - nakon formiranja, Q se više ne može menjati
  - **faktor popunjenosti**
    - $q = N / Q, \quad 0 < q \leq 1$
  - redosled smeštanja slogova u datoteku je nevažan
    - i u slučaju determinističke i probabilističke transformacije
  - slogovi se upisuju saglasno hronološkom redosledu nastanka
  - upisu sloga prethodi neuspešno traženje, na osnovu obavljene transformacije identifikatora u adresu
  - slog se smešta u baket sa izračunatom adresom

Sadržaj

- Rasute organizacije datoteka
- Direktna i relativna organizacija datoteke
- Statička rasuta organizacija datoteke
- Dinamička rasuta organizacija datoteke

Direktna i relativna organizacija datoteke

- **Direktna organizacija datoteke**
  - eksterni identifikator, trivijalna deterministička transformacija $h: A \rightarrow A$
  - vrednost identifikatora je, u isto vreme, i adresa baketa: $A_i = k_i$
    - najjednostavniji vid determinističke transformacije
  - preslikavanje veza između sadržaja slogova i adresa ne pripada direktnoj organizaciji datoteke
  - vrste direktnih datoteka, s obzirom na vrstu upotrebljavanih adresa
    - vrednosti identifikatora su mašinske adrese baketa
    - vrednosti identifikatora su relativne adrese baketa

Direktna i relativna organizacija datoteke

- **Direktna datoteka s mašinskim adresama**
  - **direktna datoteka u užem smislu reči**
  - koristi se adresa baketa na disku, oblika (*u*, *c*, *t*, *s*)
  - ima samo istorijski značaj
  - nedostaci
    - čvrsta povezanost programa sa fizičkim karakteristikama memorijskog uređaja
      - program zavisi od karakteristika eksternog memorijskog uređaja i fizički alociranog prostora na uređaju
      - ne može se koristiti putem programskih jezika treće generacije
    - odsustvo logičke veze između vrednosti identifikatora i sadržaja sloga
      - održavanje veze između sadržaja sloga i adrese je zadatak krajnjeg korisnika, ili u boljem slučaju, samog programa
      - problemi u slučaju reorganizacije ili brisanja pa upisa sloga

Direktna i relativna organizacija datoteke

- **Direktna datoteka s relativnim adresama**
  - **relativna organizacija datoteke**
  - korišćenje relativnih adresa slogova
    - lokacije alociranog memorijskog prostora numerišu se rednim brojevima od *1* do *Q* (alternativno, od *0* do *Q - 1*)
    - redni broj sloga u memorijskom prostoru predstavlja eksterni identifikator sloga
    - rešava se problem čvrste povezanosti slogova datoteke sa fizičkim karakteristikama memorijskog uređaja
  - odsustvo logičke veze između vrednosti identifikatora i sadržaja sloga – glavni nedostatak
  - **relativna metoda pristupa**
    - deo sistema za upravljanje podacima koji obavlja transformaciju relativne adrese u mašinsku i ostale operacije

Direktna i relativna organizacija datoteke

- **Relativna metoda pristupa**
  - pruža programu usluge na nivou bloka (baketa)
    - ne vrši blokiranje i rastavljanje blokova na slogove
    - prihvata samo vrednost faktora blokiranja jednaku 1
    - sa stanovišta relativne metode pristupa:

      1 blok = 1 slog
  - aktivnosti blokiranja i rastavljanja blokova na slogove moraju se realizovati u okviru samog programa
    - ukoliko za tim postoji realna potreba
    - čime se može postići veća efikasnost iskorišćenja memorijskog prostora

Direktna i relativna organizacija datoteke

- **Relativna metoda pristupa**
  - sistemi za upravljanje datotekama mainframe računarskih sistema
    - kompletna podrška – usluge na nivou bloka
  - savremeni SUBP
    - moguća podrška, ali nije tipično u upotrebi
  - standardne biblioteke programskih jezika
    - podržana transformacija relativne adrese u apsolutnu
    - moguća kompletna podrška – usluge na nivou sloga, ili
    - podrška samo direktnog pristupa lokacijama datoteke
      - rutinske operacije rada sa slogovima datoteke rešavaju se kroz aplikativni program
      - koriste se pozivi rutina koje obezbeđuju rad sa datotekom kao bajt ili znak-orijentisanom strukturom

Direktna i relativna organizacija datoteke

- **Relativna metoda pristupa**
  - standardne biblioteke programskih jezika, za razliku od sistema za upravljanje datotekama mainframe računarskih sistema
    - ne prave razliku između serijske, sekvencijalne, relativne, spregnute ili rasute osnovne organizacije datoteke
    - pružaju usluge na nivou sloga ili čak samo na nivou bajt-orijentisane strukture
    - za svaku datoteku, podržavaju metode direktnog i sekvencijalnog pristupa
    - za upravljanje svakom datotekom podržavaju iste sistemske pozive i odgovarajuće bibliotečne funkcije
      - otvaranje, pozicioniranje, čitanje, upisivanje i zatvaranje
    - aplikativnom programu ostaje da obezbedi svu funkcionalnost koju zahteva određena vrsta organizacije

Direktna i relativna organizacija datoteke

- **Formiranje relativne datoteke**
  - najčešće u posebnom postupku
  - na osnovu vodeće serijske ili neke druge vrste datoteke
    - sukcesivno učitavanje slogova vodeće datoteke
    - pridruživanje vrednosti identifikatora – relativne adrese slogu
      - najčešće automatski, kroz aplikativni program
    - smeštanje sloga u lokaciju s pridruženom relativnom adresom

Direktna i relativna organizacija datoteke

- **Traženje sloga u relativnoj datoteci**
  - traženje i logički narednog i slučajno odabranog sloga
    - zadavanjem relativne adrese lokacije metodi pristupa
      - primena trivijalne metode transformacije identifikatora u adresu
    - na osnovu adrese, metoda pristupa prenosi blok u radnu zonu programa
  - uspešno traženje
    - ako i samo ako traženi slog postoji u prenetom bloku
    - broj pristupa za uspešno ili neuspešno traženje R_u, R_n:

$$R_u = 1,\ R_n = 1$$

Direktna i relativna organizacija datoteke

- **Ažuriranje relativne datoteke**
  - u režimu direktne obrade
  - **upis novog sloga**
    - novom slogu pridruži se vrednost identifikatora
    - slog se upisuje u datoteku, ako postoji slobodna lokacija u bloku
    - pre upisa, može se izvršiti provera da li slog sa istom vrednošću ključa već postoji u istom bloku
  - **brisanje**
    - realizuje se kao logičko
    - pročita se sadržaj adresiranog bloka
    - nakon provere vrednosti ključa, izmena sadržaja statusnog polja sloga
    - modifikovani sadržaj bloka ponovo se upisuje u datoteku

Direktna i relativna organizacija datoteke

- **Ocena karakteristika relativne datoteke**
  - traženje slučajno odabranog sloga
    - najefikasnije moguće
    - uz pretpostavku da korisnik brine o vezi između sadržaja sloga i relativne adrese
  - traženje logički narednog sloga
    - značajno efikasnije nego u slučaju serijske datoteke
    - značajno manje efikasno nego u slučaju sekvencijalne datoteke
  - traženje i logički narednog i slučajno odabranog sloga
    - potreban uvek samo jedan pristup datoteci
  - uvođenje relativne adrese lokacije kao identifikatora
    - rešava problem čvrste povezanosti slogova datoteke sa karakteristikama memorijskog uređaja

Direktna i relativna organizacija datoteke

- **Ocena karakteristika relativne datoteke**
  - nepostojanje veze između vrednosti identifikatora i sadržaja sloga u relativnoj organizaciji datoteke
    - prepreka za šire korišćenje relativnih datoteka u praksi
  - moguća primena relativne metode pristupa
    - osnov za izgradnju spregnute datoteke
      - relativna adresa lokacije logički narednog sloga smešta se u polje pokazivača tekućeg sloga
    - osnov za izgradnju rasutih datoteka sa probabilističkom transformacijom ključa u adresu
      - probabilistička transformacija brine o vezi između vrednosti identifikatora i relativne adrese
    - osnov za izgradnju indeksnih datoteka
      - formira se pomoćna struktura podataka koja obezbeđuje memorisanje veze između sadržaja sloga i relativne adrese

Sadržaj

- Rasute organizacije datoteka
- Direktna i relativna organizacija datoteke
- Statička rasuta organizacija datoteke
- Dinamička rasuta organizacija datoteke

Statička rasuta organizacija datoteke

- **Opšte karakteristike rasute datoteke sa probabilističkom transformacijom**
  - ključ
    - često uzima vrednosti iz veoma velikog opsega mogućih vrednosti
      - ograničenog samo brojem pozicija *p* i brojem dozvoljenih vrednosti *v* koju svaka pozicija može imati
    - može uzimati jednu od v^p ili v^p-1 vrednosti
  - veličina adresnog prostora dodeljenog datoteci
    - broj lokacija $Q = Bb$
      - *B* - broj baketa, *b* - broj lokacija u baketu
    - *N* - broj aktuelnih slogova u datoteci
      - po pravilu, mnogo manji od broja mogućnih vrednosti ključa

$$v^p >> Q \geq N$$

Statička rasuta organizacija datoteke

- **Metode probabilističke transformacije**
  - uvode se kako bi se prevazišli nedostaci do kojih dovodi deterministička transformacija vrednosti ključa u adresu
- Ciljevi:
  - što ravnomernija raspodela slogova u adresnom prostoru
  - pseudoslučajna transformacija vrednosti ključa u adresu
  - pravilno dizajniranje potrebnog adresnog prostora

Statička rasuta organizacija datoteke

- **Metode probabilističke transformacije**
  - koraci probabilističke transformacije vrednosti ključa

$$h: dom(K) \rightarrow A$$

  - (1) pretvaranje nenumeričke u numeričku vrednost ključa:

$$k(S) \in \{0, 1, \ldots, v^p - 1\}$$

    - očekivano, osnova brojnog sistema: $v = 10$
    - p – broj cifara numeričke vrednosti ključa
  - (2) pretvaranje numeričke vrednosti ključa $k(S)$ u pseudoslučajan broj $T(k(S))$, ili skraćeno T

$$T \in \{0, 1, \ldots, v^n - 1\}$$

    - n – dozvoljeni broj cifara relativne adrese $A \in \{1, \ldots, B\}$

$$n = \lceil \log_v B \rceil, \quad 1 \leq n \leq p$$

Statička rasuta organizacija datoteke

- **Metode probabilističke transformacije**
  - koraci probabilističke transformacije vrednosti ključa

$$h: dom(K) \rightarrow A$$

  - (3) dovođenje vrednosti pseudoslučajnog broja T u opseg dozvoljenih vrednosti relativne adrese $\{1,\ldots, B\}$

$$A = 1 + \lfloor kT \rfloor, \quad k = \frac{B}{v^n}, \quad 0{,}1 < k \leq 1$$

    - $A \in \{1,\ldots, B\}$
  - (4) pretvaranje relativne u mašinsku adresu
    - opšti zadatak metode pristupa
    - rezultat primene prva tri koraka je relativna adresa

Statička rasuta organizacija datoteke

- **Metode probabilističke transformacije**
  - tri često upotrebljavane metode
    - **metoda ostatka pri deljenju**
    - **metoda centralnih cifara kvadrata ključa**
    - **metoda preklapanja**

Statička rasuta organizacija datoteke

- **Metoda ostatka pri deljenju**
  - relativna adresa *A* – celobrojni ostatak pri deljenju numeričke vrednosti ključa

$$T = k(S) (\mathrm{mod}\, m)$$

  - *m* – ceo broj, takav da:

$$v^{n-1} < m \leq v^{n}$$

$$A = 1 + \left\lfloor \frac{B}{m} T \right\rfloor, \quad k = \frac{B}{m}, \quad 0{,}1 < k \leq 1$$

  - kada se izabere da je *m* = *B*:

$$A = 1 + k(S) (\mathrm{mod}\, B)$$

Statička rasuta organizacija datoteke

- **Metoda ostatka pri deljenju**
  - preporuke za izbor vrednosti *m*
    - kako bi rezultat transformacije bio što slučajniji broj, a transformacija što ravnomernija
  - *m* ne treba da bude paran broj, jer tada
    - neparne vrednosti ključa daju neparne vrednosti relativne adrese, a
    - parne vrednosti ključa daju parne adrese
  - *m* ne treba da bude stepen osnove brojnog sistema
    - jer bi tada cifre najmanje težine ključa predstavljale relativnu adresu bez obzira na vrednost ostalih cifara
  - najpogodnije da *m* predstavlja
    - prost broj ili
    - neparan broj sa relativno velikim prostim činiocima

Statička rasuta organizacija datoteke

- **Metoda ostatka pri deljenju**

$$A = 1 + k(S) (\mathrm{mod}\ B)$$

  - Primer: $B = 5$, $m = B$

S_i	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9
$k(S_i)$	34	7	3	15	19	29	64	43	23
T_i	4	2	3	0	4	4	4	3	3
A_i	5	3	4	1	5	5	5	4	4

Statička rasuta organizacija datoteke

- **Metoda ostatka pri deljenju**
  - pogodna za primenu kada se vrednosti ključa javljaju u paketima
    - pojedini intervali u opsegu dozvoljenih vrednosti ključa gusto zaposednuti aktuelnim vrednostima ključa
    - između njih intervali sa neaktuelnim vrednostima ključa

  - slogovi sa sukcesivnim vrednostima ključa iz paketa dobijaju adrese fizički susednih baketa
    - što rezultuje ravnomernim zaposedanjem baketa

Statička rasuta organizacija datoteke

- **Metoda centralnih cifara kvadrata ključa**
  - vrednost ključa diže se na kvadrat
  - uzima se onoliko centralnih cifara kvadrata vrednosti ključa koliko pozicija treba da sadrži relativna adresa
    - formira se pseudoslučajan broj *T*
  - vrši se centriranje i normiranje pseudoslučajnog broja na zadati opseg relativnih adresa

Statička rasuta organizacija datoteke

- **Metoda centralnih cifara kvadrata ključa**
  - vrednost ključa $k(S) \in \{0, 1,\ldots, v^p - 1\}$ u polinomijalnom obliku:

$$k(S) = \sum_{i=0}^{p-1} a_i v^i, \; a_i \in \{0, 1, \ldots, v-1\}$$

  - kvadrat u vrednosti ključa u polinomijalnom obliku:

$$(k(S))^2 = \sum_{i=0}^{2p-1} c_i v^i, c_i \in \{0, 1, \ldots, v-1\}$$

Statička rasuta organizacija datoteke

- **Metoda centralnih cifara kvadrata ključa**
  - iz niza cifara kvadrata ključa (c_{2p-1}, c_{2p-2},..., c_1, c_0) izdvaja se podniz od n centralnih cifara

$$(c_{t+n-1}, c_{t+n-2},\ldots,c_{t+1},c_t)$$

    - t – pozicija najlakše cifre podniza

$$t = \left\lfloor p - \frac{n}{2} \right\rfloor$$

    - formira se pseudoslučajni broj T:

$$T = \sum_{i=0}^{n-1} c_{t+i} v^i$$

  - relativna adresa matičnog baketa A:

$$A = 1 + \left\lfloor \frac{B}{v^n} T \right\rfloor$$

Statička rasuta organizacija datoteke

- **Metoda centralnih cifara kvadrata ključa**
  - Primer:
    - $p = 2$, $v = 10$,
    - $B = 20$, $n = 2$,
    - $t = 1$, $k = B / v^n = 0{,}2$

$$A = 1 + \left\lfloor \frac{B}{v^n} T \right\rfloor$$

S_i	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9
$k(S_i)$	34	7	3	15	19	29	64	43	23
$(k(S_i))^2$	1156	0049	0009	0225	0361	0841	4096	1849	0529
T_i	15	04	00	22	36	84	09	84	52
A_i	4	1	1	5	8	17	2	17	11

Statička rasuta organizacija datoteke

- **Metoda preklapanja**
  - cifre ključa premeštaju se kao pri savijanju, tj. preklapanju hartije
  - vrši se sabiranje preklopljenih vrednosti po modulu v^n
  - pogodna za primenu
    - kada je broj pozicija vrednosti ključa *p* mnogo veći od broja pozicija relativne adrese *n*
  - preklapanje se izvodi po osama koje zdesna u levo određuje broj pozicija *n* relativne adrese

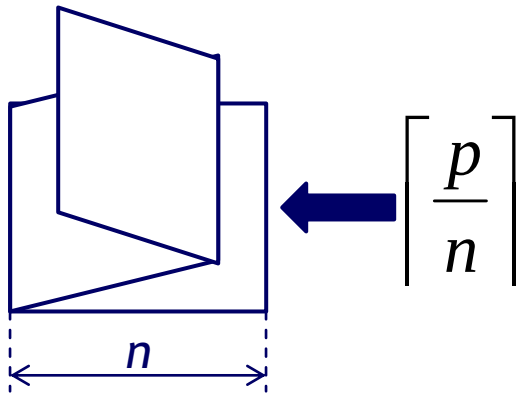

$\left\lceil \frac{p}{n} \right\rceil$ segmenata (brojeva) za preklapanje

Statička rasuta organizacija datoteke

- **Metoda preklapanja**
  - vrednost ključa $k(S) \in \{0, 1,\ldots, v^p - 1\}$ u polinomijalnom obliku:

$$k(S) = \sum_{i=0}^{p-1} a_i v^i, \; a_i \in \{0, 1, \ldots, v-1\}$$

  - pseudoslučajan broj T

$$T = \left(\sum_{k=0}^{q} \sum_{i=0}^{n-1} c_r v^i + \sum_{k=1}^{q} \sum_{i=0}^{n-1} c_s v^i \right) (\mathrm{mod}\, v^n)$$

$$q = \left\lfloor \frac{p}{2n} \right\rfloor, \; r = 2kn + i, \; s = 2kn - i - 1$$

$$c_r = \begin{cases} c_r, & za \;\; r < p \\ 0, & za \;\; r \geq p \end{cases} \quad \text{i} \quad c_s = \begin{cases} c_s, & za \;\; s < p \\ 0, & za \;\; s \geq p \end{cases}$$

Statička rasuta organizacija datoteke

- **Metoda preklapanja**
  - relativna adresa matičnog baketa A:

$$A = 1 + \left\lfloor \frac{B}{v^n} T \right\rfloor$$

  - Primer:
    - $p = 6$, $v = 10$,
    - $B = 20$, $n = 2$,
    - $\lceil p / n \rceil = 3$, $k = B / v^n = 0{,}2$
    - $k(S_1) = 341201$, $T_1 = (01 + 21 + 34) \bmod 10^2 = 56$

S_i	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9
$k(S_i)$	341201	237896	465210	542812	191378	296532	641000	430025	231258
T_i	56	6	81	48	28	17	65	68	2
A_i	12	2	17	10	6	4	14	14	1

Statička rasuta organizacija datoteke

- **Karakteristike probabilističke transformacije**
  - pojava slogova **sinonima**
    - dve različite vrednosti ključa mogu transformacijom dobiti istu relativnu adresu
    - slogovi sinonimi – slogovi koji transformacijom dobiju iste relativne adrese

$$k(S_i) \neq k(S_j),\ h(k(S_i)) = h(k(S_j))$$

  - **matični baket**
    - baket čija relativna adresa predstavlja rezultat transformacije
    - slogovi se uvek smeštaju u matični baket dok se ne popuni
  - **primarni slog**
    - slog koji je smešten u matični baket
  - metoda transformacije particionira skup mogućih vrednosti ključa na *B* skupova sinonima

Statička rasuta organizacija datoteke

- **Karakteristike probabilističke transformacije**
  - **prekoračilac**
    - slog koji ne može biti smešten u matični baket, usled njegove popunjenosti
    - mora se smestiti u neki drugi baket
      - definiše se poseban postupak za smeštanje prekoračilaca
  - pojava prekoračilaca je nepoželjna, jer
    - zahteva poseban postupak za pronalaženje nove slobodne lokacije za smeštaj prekoračilaca
    - dovodi do produženja vremena pristupa pri kasnijem traženju slogova prekoračilaca

Statička rasuta organizacija datoteke

- **Karakteristike probabilističke transformacije**
  - verovatnoća pojave sinonima zavisi od
    - raspodele vrednosti ključa unutar opsega dozvoljenih vrednosti
    - odabrane metode transformacije
    - faktora popunjenosti memorijskog prostora

$$q = \frac{N}{Q} = \frac{N}{bB}$$

  - broj prekoračilaca će biti manji
    - što su slogovi ravnomernije raspoređeni po baketima
    - što je faktor popunjenosti manji
    - što je faktor baketiranja veći
  - pojava prekoračilaca je neminovnost

Statička rasuta organizacija datoteke

- **Karakteristike probabilističke transformacije**
  - izbor faktora popunjenosti
    - ostvaruje veliki uticaj na karakteristike rasuto organizovane datoteke
  - za malo q
    - verovatnoća pojave više slogova u jednom skupu sinonima je takođe mala ali je malo i iskorišćenje memorijskog prostora
  - za veliko q (blizu 1)
    - iskorišćenje memorijskog prostora je dobro, ali je velika verovatnoća pojave sinonima i prekoračilaca
  - u praksi se bira $q \leq 0,8$

Statička rasuta organizacija datoteke

- **Karakteristike probabilističke transformacije**
  - izbor faktora baketiranja
    - utiče na očekivani broj prekoračilaca po jednom baketu, pri datom faktoru popunjenosti *q*
  - s porastom faktora baketiranja *b*
    - verovatnoća pojave prekoračilaca opada
    - ali raste vreme razmene sadržaja baketa između diska i OM
      - putem jednog baketa učitava se veći broj, potencijalno nepotrebnih slogova u OM
  - sa smanjenjem faktora baketiranja *b*
    - povećava se očekivani broj prekoračilaca
    - za isti *N* i *q* povećava se broj baketa *B* i poboljšava se preciznost transformacije
  - u praksi, bira se $b \leq 10$

Statička rasuta organizacija datoteke

- **Projektovanje rasute datoteke**
  - pri projektovanju utvrđuju se
    - faktor popunjenosti memorijskog prostora *q*
    - faktor baketiranja *b*
    - metoda transformacije vrednosti ključa u adresu
    - postupak za smeštanje prekoračilaca
  - ova opredeljenja donose se s obzirom na
    - raspodelu vrednosti ključa unutar opsega mogućnih vrednosti
    - veličinu sloga
    - obim i karakter ažuriranja datoteke
    - očekivani srednji broj pristupa datoteci pri uspešnom i neuspešnom traženju

Statička rasuta organizacija datoteke

- **Postupci za smeštaj prekoračilaca**
  - **smeštaj svih prekoračilaca unutar jedinstvenog adresnog prostora**
    - izbor posebnog postupka za pronalaženje prazne lokacije za smeštaj prekoračioca
  - **smeštaj svih prekoračilaca u posebnu zonu adresnog prostora**
    - datoteka poseduje dve zone, primarnu i zonu prekoračenja
      - prekoračioci se smeštaju u neku od slobodnih lokacija unutar zone prekoračenja
    - izbor vrste fizičke organizacije zone prekoračenja
  - **kombinacija prethodna dva načina**
    - lokalne zone prekoračenja u okviru primarne zone
    - glavna zona prekoračenja – posebna zona

Rasute organizacije datoteka

Primarna zona

1					
	15	$p(S_4)$	25	$p(S_7)$		
2						
3						
	07	$p(S_2)$	27	$p(S_9)$		
4						
	03	$p(S_3)$	23	$p(S_8)$	13	$p(S_{10})$
5						
	34	$p(S_1)$	19	$p(S_5)$	29	$p(S_6)$

Zona prekoračenja

Statička rasuta organizacija datoteke

- **Projektovanje i formiranje rasute datoteke**
  - za zadati *b*, *q* i *N*, broj baketa je:

$$B = \left\lceil \frac{N}{bq} \right\rceil$$

  - aktivnosti formiranja rasuto organizovane datoteke realizuju se
    - potpuno uz pomoć metode pristupa, ako je podržava ili
    - delom uz pomoć aplikativnog programa i delom uz pomoć relativne metode pristupa
      - aplikativni program: transformacija vrednosti ključa, smeštanje prekoračilaca, formiranje baketa od više slogova, izdvajanje slogova iz baketa
      - relativna metoda: direktni upis i čitanje sadržaja baketa

Statička rasuta organizacija datoteke

- **Formiranje rasute datoteke**
  - (1) inicijalno alociranje prazne datoteke
    - statička alokacija kompletnog praznog prostora datoteke
    - izbor postupka prepoznavanja slobodnih lokacija unutar baketa
      - putem sadržaja statusnog polja
      - upisom specijalnih znakova u lokaciju
      - putem indeksa slobodnih lokacija i njihovog sprezanja
  - (2) upisivanje slogova u rasutu datoteku
    - saglasno opštem postupku formiranja rasutih datoteka
    - na osnovu sadržaja vodeće datoteke kojoj se sekvencijalno pristupa ili
    - direktnim upisivanjem slogova u realnom vremenu

Statička rasuta organizacija datoteke

- **Formiranje rasute datoteke**
  - **(A) Formiranje u jednom prolazu**
  - **(B) Formiranje u dva prolaza**

  - **(A) Formiranje u jednom prolazu**
    - slogovi se upisuju u hronološkom redosledu nastanka
      - bilo čitanjem sadržaja vodeće datoteke u sekvencijalnom pristupu, bilo direktnim unosom podataka u realnom vremenu

Rasute organizacije datoteka

39,24,33,6

06 →

1						
	15	$p(S_4)$	25	$p(S_7)$	5	$p(S_{11})$
2						
	39		24		33	
3						
	07	$p(S_2)$	27	$p(S_9)$	06	
4						
	03	$p(S_3)$	23	$p(S_8)$	13	$p(S_{10})$
5						
	34	$p(S_1)$	19	$p(S_5)$	29	$p(S_6)$

Transformacija
$h(k_i)=1+k(S_i)(\text{mod } B)$

Statička rasuta organizacija datoteke

- **Formiranje rasute datoteke**
  - **(B) Formiranje u dva prolaza**
    - slogovi se učitavaju iz vodeće datoteke i upisuju u rasutu
    - **(I) Prvi prolaz**
      - upisuju se samo oni slogovi koji će biti smešteni u matične bakete
    - **(II) Drugi prolaz**
      - upisuju se preostali slogovi – prekoračioci, saglasno izabranom postupku za smeštanje prekoračilaca
    - ima smisla kod datoteka sa jedinstvenim adresnim prostorom
      - time se umanjuje ukupan broj prekoračilaca

Statička rasuta organizacija datoteke

- **Traženje sloga u rasutoj datoteci**
  - traženje logički narednog = slučajno odabranog sloga
    - vrši se metodom transformacije argumenta u adresu baketa
  - ako se slog ne nađe u matičnom baketu, a matični baket ima prekoračilaca, traženje se nastavlja
    - saglasno izabranom postupku za smeštanje i traženje prekoračilaca
      - linearna metoda
      - ponovna transformacija
      - metoda praćenja pokazivača
  - za zadati *q* i *b*, efikasnost traženja zavisi od primenjenog postupka za smeštaj prekoračilaca

Statička rasuta organizacija datoteke

- **Vrste statičkih rasutih organizacija**
  - **rasute datoteke s jedinstvenim adresnim prostorom**
    - datoteka sa linearnim traženjem lokacije za smeštaj prekoračilaca – sa otvorenim načinom adresiranja
      - s fiksnim korakom k, $k \geq 1$
      - sa slučajno odbarnim korakom k, $k \geq 1$
    - datoteka sa sprezanjem prekoračilaca u jedinstvenom adresnom prostoru – primarnoj zoni
  - **rasute datoteke sa zonom prekoračenja**
    - sa serijskom zonom prekoračenja
    - sa spregnutom zonom prekoračenja

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **s fiksnim korakom *k*, *k* = 1**
  - ukoliko je matični baket popunjen, slog se smešta u prvu narednu slobodnu lokaciju
    - s obzirom na poziciju matičnog baketa

$$A_0 = h(k(S))$$

$$A_n = 1 + A_{n-1} \bmod B, \text{ za } n \geq 1$$

  - **traženje slučajno odabranog sloga - prekoračioca**
    - linearnom metodom
    - zaustavlja se na
      - a) pronađenom slogu, ako je uspešno
      - b) prvoj slobodnoj lokaciji, ako je neuspešno
      - c) ponovnim nailaskom na matični baket, ako je neuspešno, a cela datoteka kompletno popunjena

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **s fiksnim korakom *k*, *k* = 1**
  - **upis novog sloga - prekoračioca**
    - pronalaženjem prve slobodne lokacije iza matičnog baketa
  - **brisanje postojećeg sloga**
    - **logičko**, potrebna tri statusa sloga
      - a) aktuelan, b) neaktuelan i c) slobodna lokacija
    - **fizičko**, uz lokalnu reorganizaciju memorijskog prostora
      - primarnog sloga, kada ne postoje prekoračioci
        - oslobađa se lokacija
      - primarnog sloga, kada postoje prekoračioci ili prekoračioca
        - svi prekoračioci (ne samo za dati matični baket) pomeraju se za jednu poziciju prema matičnom baketu
        - pri pomeranju, prekoračilac ne sme da pređe ispred svog matičnog baketa

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **s fiksnim korakom *k*, *k* = 1**
- glavni nedostaci
  - **(A) efekat nagomilavanja prekoračilaca**
    - prekoračioci iz jednih baketa izazivaju pojavu prekoračilaca iz drugih baketa
    - sve više raste verovatnoća zauzeća prve prazne lokacije iza sve dužeg lanca zauzetih lokacija
  - **(B) neefikasno traženje**
    - traženje se vrši i u baketima koji ne sadrže slogove iz istog skupa sinonima
  - **(C) neefikasno neuspešno traženje**
    - zaustavlja se tek nailaskom na prvu slobodnu lokaciju

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **s fiksnim korakom *k*, *k* > 1**
  - ukoliko je matični baket popunjen, slog se smešta u narednu slobodnu lokaciju, udaljenu za *k* > 1 pozicija
    - s obzirom na poziciju matičnog baketa

$$A_0 = h(k(S))$$

$$A_n = 1 + (A_{n-1} + k - 1) \bmod B, \text{ za } n \geq 1$$

  - *k* i *B* moraju biti uzajamno prosti brojevi
    - kako bi se obezbedio, u najgorem slučaju, siguran obilazak svih mogućih baketa
      - u cilju pronalaska prve slobodne lokacije

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **s fiksnim korakom *k*, *k* > 1**
- glavna motivacija
  - odlaganje efekta nagomilavanja prekoračilaca
- pozitivan efekat
  - prekidanje dugačkih lanaca zauzetih lokacija
    - pokušaj da se, koliko je to moguće, očuva približno jednaka verovatnoća zauzeća bilo koje prazne lokacije

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **sa slučajno odabranim korakom *k*, *k* ≥ 1**
  - **Rasuta datoteka sa slučajnim traženjem**
  - ukoliko je matični baket popunjen, slog se smešta u narednu slobodnu lokaciju, udaljenu za *k* ≥ 1 pozicija
    - s obzirom na poziciju matičnog baketa
  - *k* se određuje na slučajan način
    - predstavlja rezultat druge probabilističke transformacije, primenjene na vrednost identifikatora – ključa sloga

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **sa slučajno odabranim korakom k, $k \geq 1$**
  - dve probabilističke transformacije

$$A_0 = h_1(k(S)) \in \{1,\ldots, B\}$$

$$k = h_2(k(S)) \in \{1,\ldots, B - 1\}$$

$$A_n = 1 + (A_{n-1} + k - 1) \bmod B, \text{ tj.}$$

$$A_n = 1 + (A_{n-1} + h_2(k(S)) - 1) \bmod B, \text{ za } n \geq 1$$

  - k i B moraju biti uzajamno prosti brojevi
    - kako bi se obezbedio, u najgorem slučaju, siguran obilazak svih mogućih baketa
      - u cilju pronalaska prve slobodne lokacije
    - pošto je k slučajna veličina, bira se da B bude prost broj
    - često, $k = h_2(k(S)) = 1 + k(S) \bmod (B - 1)$

Statička rasuta organizacija datoteke

- **Rasuta s linearnim traženjem prekoračilaca**
  - **sa slučajno odabranim korakom k, $k \geq 1$**
- glavna motivacija
  - izbegavanje efekta nagomilavanja prekoračilaca
- pozitivan efekat
  - prekidanje dugačkih lanaca zauzetih lokacija
    - bolji pokušaj da se, koliko je to moguće, očuva približno jednaka verovatnoća zauzeća bilo koje prazne lokacije
- **Rasute s otvorenim načinom adresiranja**
  - pogodne za upotrebu u slučaju
    - manje popunjenosti, $q \leq 0{,}7$
    - nižeg intenziteta ažuriranja

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u primarnoj zoni**
  - primena tehnike sprezanja i složenija fizička struktura
  - ukoliko je matični baket popunjen, slog se smešta u prvu slobodnu lokaciju iz lanca slobodnih lokacija
    - sprežu se dvostruko baketi sa slobodnim lokacijama
    - specijalan (nulti) baket s pokazivačem na početak lanca
  - vrši se sprezanje svih sinonima u odnosu na matični baket
    - za svaki matični baket po jedan lanac sinonima
    - pokazivač na početak lanca u zaglavlju matičnog baketa
    - pokazivač na sledeći u lancu sinonima ugrađen u svaki slog

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u primarnoj zoni**
  - format baketa i sloga

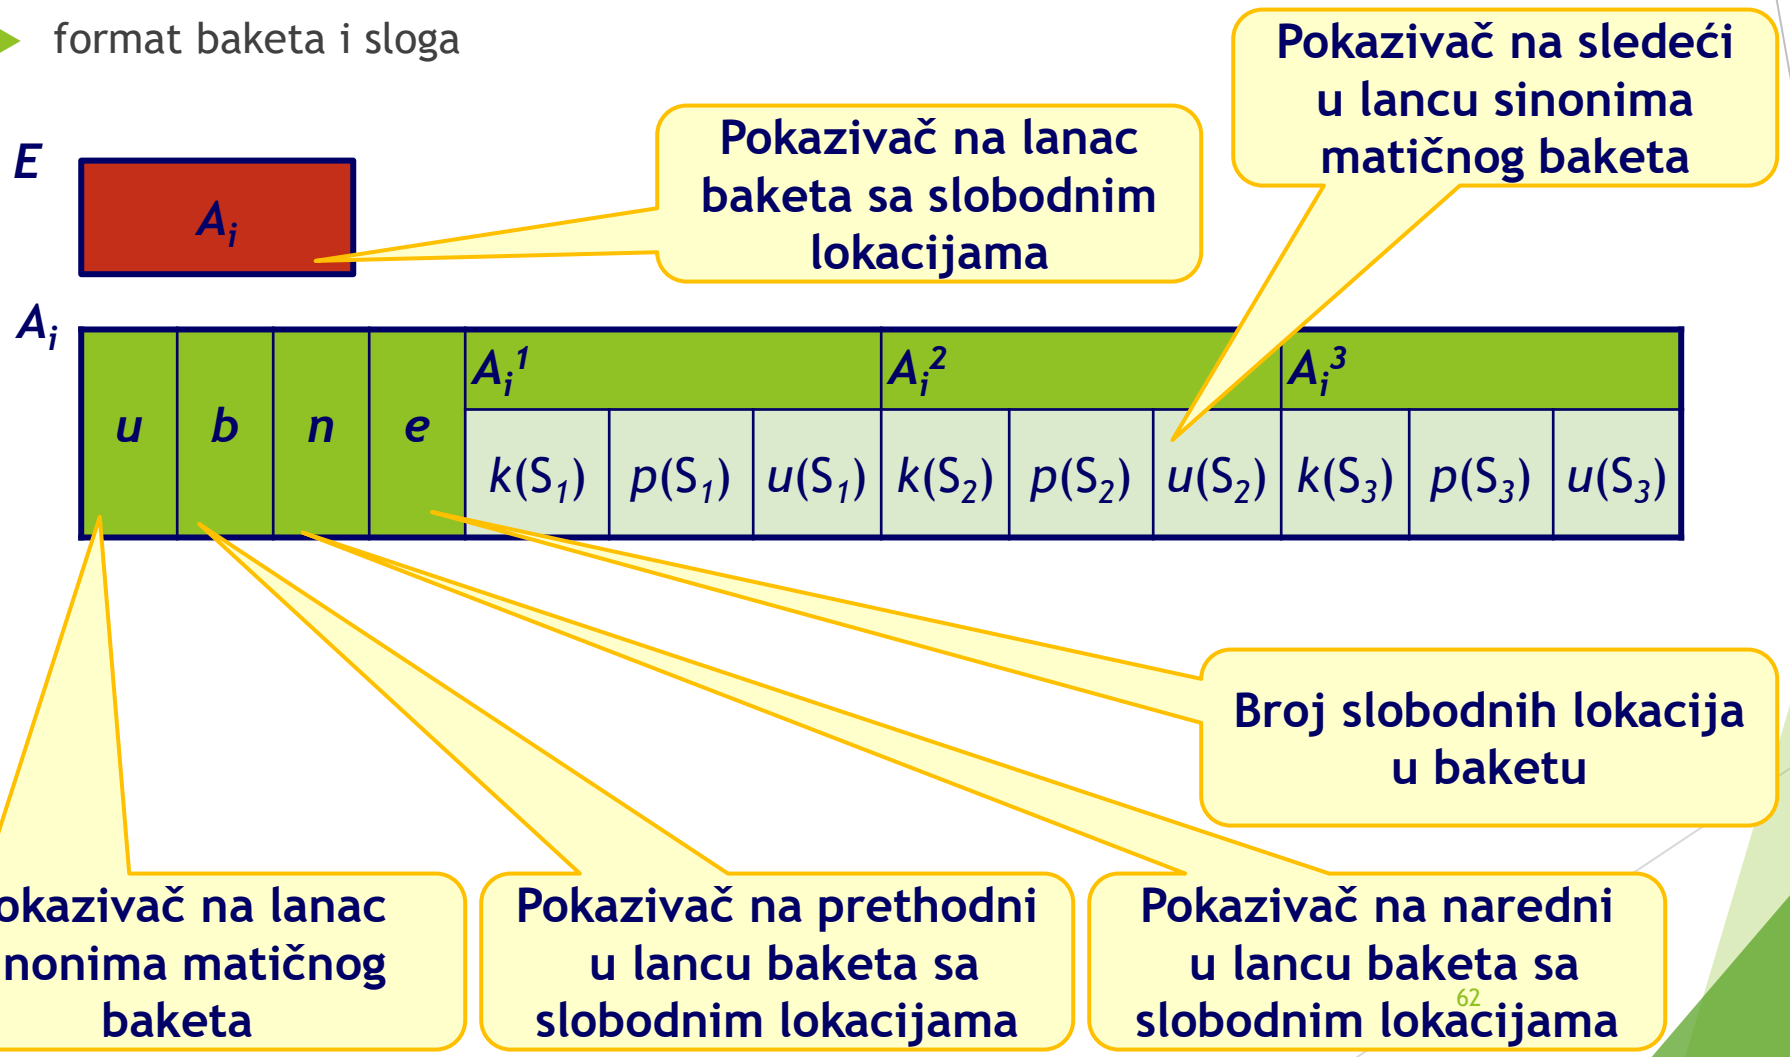

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u primarnoj zoni**
  - **traženje slučajno odabranog sloga**
    - transformacija vrednosti ključa u adresu $A = h(k(S))$ i pristupanje matičnom baketu
    - praćenje lanca sinonima, započinjući od pokazivača *u*
      - metodom praćenja pokazivača
    - zaustavlja se na
      - a) pronađenom slogu, ako je uspešno
      - b) kraju lanca sinonima, ako je neuspešno

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u primarnoj zoni**
  - **upis novog sloga**
    - nakon neuspešnog traženja, uvezivanjem u lanac sinonima
    - izborom prve prazne lokacije iz lanca baketa sa slobodnim lokacijama
      - na koju ukazuje *E*
  - **brisanje postojećeg sloga**
    - **fizičko**
    - uklanjanjem sloga iz lanca sinonima, uz potrebno prevezivanje
    - oslobađanje lokacije, uz eventualno vraćanje baketa u lanac baketa sa slobodnim lokacijama

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u primarnoj zoni**
- glavna motivacija
  - izbegavanje efekata neefikasnog traženja (B) i (C)
    - traženje se vrši samo u baketima koji sadrže slogove iz istog skupa sinonima
    - neuspešno traženje zaustavlja se dolaskom do kraja lanca spregnutih slogova - sinonima
- pozitivan efekat
  - poboljšana efikasnost traženja (naročito neuspešnog)
    - u odnosu na datoteke s otvorenim načinom adresiranja
- negativan efekat
  - i dalje moguć efekat nagomilavanja prekoračilaca (A)
  - komplikovanija fizička struktura

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u zoni prekoračenja**
  - uvođenje zone prekoračenja – spregnuta datoteka
  - primena tehnike sprezanja i složenija fizička struktura
  - ukoliko je matični baket popunjen, slog se smešta u prvu slobodnu lokaciju iz lanca slobodnih lokacija u zoni prekoračenja
    - sprežu se jednostruko baketi sa slobodnim lokacijama u zoni prekoračenja
    - specijalan (nulti) baket s pokazivačem na početak lanca
  - vrši se sprezanje svih prekoračilaca
    - za svaki matični baket po jedan lanac prekoračilaca
    - pokazivač na početak lanca u zaglavlju matičnog baketa
    - pokazivač na sledeći u lancu prekoračilaca ugrađen u svaki slog u zoni prekoračenja

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u zoni prekoračenja**
  - dimenzionisanje spregnute zone prekoračenja
  - tipičan faktor blokiranja f = 1
    - mala je verovatnoća da se dva prekoračioca iz istog lanca sinonima nađu u susednim lokacijama
  - **formiranje**
    - uvek u jednom prolazu
    - svi prekoračioci su u zoni prekoračenja, koja je odvojena od primarne zone

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u zoni prekoračenja**
  - **traženje slučajno odabranog sloga**
    - transformacija vrednosti ključa u adresu $A = h(k(S))$ i pristupanje matičnom baketu
    - praćenje lanca prekoračilaca, započinjući od pokazivača na početak lanca u matičnom baketu
      - ukoliko slog nije pronađen u matičnom baketu, a postoji lanac prekoračilaca
      - metodom praćenja pokazivača
    - zaustavlja se na
      - a) pronađenom slogu, ako je uspešno
      - b) kraju lanca prekoračilaca, ako je neuspešno

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u zoni prekoračenja**
  - **upis novog sloga**
    - nakon neuspešnog traženja
    - u matični baket, ako ima mesta
    - uvezivanjem u lanac prekoračilaca, ako u matičnom baketu nema mesta
    - izborom prve prazne lokacije iz lanca baketa sa slobodnim lokacijama u zoni prekoračenja
      - na koju ukazuje pokazivač na početak lanca
  - **brisanje postojećeg sloga**
    - **fizičko**
    - uklanjanjem sloga iz matičnog baketa uz, eventualno, prebacivanje prvog prekoračioca u matični baket, ili
    - uklanjanjem sloga iz lanca prekoračilaca, uz potrebno prevezivanje

Statička rasuta organizacija datoteke

- **Rasuta sa sprezanjem u zoni prekoračenja**
- glavna motivacija
  - izbegavanje efekata neefikasnog traženja (B) i (C)
    - traženje se vrši samo u baketima koji sadrže slogove iz istog skupa sinonima
    - neuspešno traženje zaustavlja se dolaskom do kraja lanca spregnutih slogova – sinonima
  - uklanjanje efekta nagomilavanja prekoračilaca (A)
    - svi prekoračioci u zoni prekoračenja – spregnuta datoteka
- pozitivan efekat
  - poboljšana efikasnost traženja (naročito neuspešnog)
    - u odnosu na datoteke s jedinstvenim adresnim prostorom

Statička rasuta organizacija datoteke

- **Rasuta sa serijskom zonom prekoračenja**
  - uvođenje zone prekoračenja – serijska datoteka
  - ukoliko je matični baket popunjen, slog se smešta u prvu slobodnu lokaciju u serijskoj zoni prekoračenja
  - jednostavna struktura
    - nema dodatnih polja pokazivača
  - pogodna u slučaju manjeg očekivanog ukupnog broja prekoračilaca
    - ne isplati se sprezanje prekoračilaca u zoni prekoračenja

Statička rasuta organizacija datoteke

- **Ocena traženja sloga u rasutoj datoteci**
  - očekivani broj prekoračilaca po jednom slogu

$$\frac{\overline{LB}}{N} = \frac{q-1}{q} - \frac{1}{qb}\sum_{i=0}^{b}(i-b)P(i)$$

  - pri zadatom *q* i *b* ne zavisi od broja slogova *N*
    - odnos *N* / *B* je konstantan
  - očekivani broj pristupa pri uspešnom i neuspešnom traženju zavisi od *q* i *b*, a ne od *N*
  - karakteristike velikih rasutih datoteka mogu se procenjivati poređenjem s malim datotekama, ali sa istim *q* i *b*

Statička rasuta organizacija datoteke

- **Ocena traženja sloga u rasutoj datoteci**
  - očekivani broj pristupa za uspešno traženje slučajno odabranog sloga, kod svih vrsta

$$\overline{R}_u = \frac{1}{N}\sum_{i=1}^{N} R_i^u$$

    - prebroji se potreban broj pristupa za svaki pojedinačni slog
  - očekivani broj pristupa za neuspešno traženje slučajno odabranog sloga, kod svih vrsta
    - osim kod datoteke sa slučajnim traženjem prekoračilaca

$$\overline{R}_n = \frac{1}{B}\sum_{i=1}^{B} R_i^n$$

    - prebroji se potreban broj pristupa za svaki matični baket

Statička rasuta organizacija datoteke

- **Ocena traženja sloga u rasutoj datoteci**
  - očekivani broj pristupa za neuspešno traženje slučajno odabranog sloga
    - kod datoteke sa slučajnim traženjem prekoračilaca

$$\overline{R}_n = \frac{1}{T}\sum_{i=1}^{T} R_i^n \quad \text{ili} \quad \overline{R}_n = \frac{1}{B(B-1)}\sum_{i=1}^{B(B-1)} R_i^n$$

    - prebroji se potreban broj pristupa za
      - svaku neaktuelnu vrednost ključa, $T = v^p - N$ ili
      - svaki matični baket i svaku moguću vrednost koraka $k \in \{1,\ldots, B - 1\}$

Statička rasuta organizacija datoteke

- **Obrada rasute datoteke sa probabilističkom transformacijom**
  - nepogodne za korišćenje u ulozi osnovne (prve) vodeće datoteke
  - mogu se koristiti kao obrađivane i vodeće u režimu direktne obrade
  - ne mogu se koristiti kao vodeće u režimu redosledne obrade
    - pošto fizička struktura ne sadrži informaciju o logičkoj strukturi podataka
  - mogu se obrađivati i u režimu redosledne i u režimu direktne obrade

Statička rasuta organizacija datoteke

- **Obrada rasute datoteke sa probabilističkom transformacijom**
  - performanse redosledne i direktne obrade rasute datoteke su iste
    - zbog iste efikasnosti traženja i logički narednog i slučajno odabranog sloga
  - očekivani ukupni broj pristupa

$$\overline{R}_{uk} = N_v^u \overline{R}_u + N_v^n \overline{R}_n$$

    - broj slogova vodeće datoteke

$$N_v = N_v^u + N_v^n$$

    - $\overline{R}_u$ očekivani broj pristupa pri uspešnom traženju 1 sloga
    - $\overline{R}_n$ očekivani broj pristupa pri neuspešnom traženju 1 sloga

Statička rasuta organizacija datoteke

- **Oblasti primene rasutih datoteka**
  - u svim mrežnim SUBP
  - u pojedinim relacionim SUBP
  - u interaktivnoj obradi podataka
  - u režimu paketne obrade
  - prednost
    - mali očekivani broj pristupa pri traženju slučajno odabranog sloga

Statička rasuta organizacija datoteke

- **Oblasti primene rasutih datoteka**
  - nedostaci
    - potreba da se unapred odredi veličina datoteke
      - pogodne samo za datoteke čiji se sadržaj ređe menja
      - intenzivno upisivanje novih slogova dovodi do degradacije performansi obrade
    - problem izbora probabilističke transformacije
      - ravnomerna raspodela broja sinonima po baketima i pri formiranju i pri ažuriranju
    - broj pristupa pri traženju može biti nepredvidivo velik

Sadržaj

- Rasute organizacije datoteka
- Direktna i relativna organizacija datoteke
- Statička rasuta organizacija datoteke
- Dinamička rasuta organizacija datoteke

Dinamička rasuta organizacija datoteke

- **Dinamička rasuta datoteka**
  - osnovni nedostatak statičkih rasutih datoteka
    - uzajamna zavisnost metode transformacije identifikatora u relativnu adresu i veličine adresnog prostora dodeljenog datoteci
    - dolazi do pojave prekoračilaca
    - dolazi do degradacije performansi obrade datoteke
  - za datoteke koje se skoro isključivo obrađuju u režimu direktne obrade i čiji se sadržaj intenzivno menja
    - moguće je uvesti rasutu organizaciju koja će se dinamički prilagođavati aktuelnom broju slogova u datoteci

Dinamička rasuta organizacija datoteke

- **Dinamička rasuta datoteka**
  - više vrsta struktura dinamičkih rasutih datoteka
    - rasute datoteke koje se mogu širiti
    - dinamičke rasute datoteke
    - linearne dinamičke rasute datoteke
  - zajedničke osobine
    - metoda transformacije *h*
      - ne zavisi od veličine adresnog prostora dodeljenog datoteci
      - ne menja se zbog upisa novih slogova ili brisanja postojećih
    - rezultat primene *h* na vrednost ključa
      - binaran broj maksimalne dužine d_{max}
      - vodećih d ($0 \leq d \leq d_{max}$) bitova rezultata transformacije je vrednost transformacije *vt*
      - *vt* se koristi za pronalaženje adrese baketa u kojem je slog
    - dužina *d* i broj baketa *B* se povećavaju i smanjuju dinamički

Dinamička rasuta organizacija datoteke

- **Struktura dinamičke rasute datoteke**
  - dva dela
    - **adresar**
      - sadrži niz pokazivača dužine 2^d ($d \geq 0$) sa adresama baketa i druga polja (uključujući i d i faktor baketiranja b)
    - **zona podataka sa baketima**
      - svaki baket sadrži zaglavlje i bar jedan slog
      - zaglavlje baketa sadrži
        - polje d' ($0 \leq d' \leq d$) sa lokalnom dužinom vrednosti transformacije
        - polje m sa brojem aktuelnih slogova u baketu
      - d' govori koliko istih bitova najveće težine vrednosti transformacije vt moraju imati svi slogovi u baketu
  - adresar i zona podataka
    - realizuju se kao dve posebne datoteke

Dinamička rasuta organizacija datoteke

- **Adresar**
  - mala pomoćna struktura podataka
    - kao indeks koristi se za pristup baketima na disku
  - najčešće se realizuje kao linearna struktura
  - adresar sadrži
    - jednodimenzionalni niz od 2^d ($\geq B$) pokazivača ka baketima u zoni podataka, gde je B broj aktuelnih baketa u zoni podataka
    - promenljivu d
      - broj bitova najveće težine funkcije $h(k)$ koji se trenutno koriste za indeksiranje niza pokazivača
    - faktor baketiranja b

Dinamička rasuta organizacija datoteke

- **Adresar**
  - koristi se samo stvarno neophodni broj bitova za adresiranje baketa

$$d = \lceil \log_2 B \rceil$$

  - adresar zahteva relativno mali kapacitet memorijskog prostora
    - ceo adresar može smestiti u OM
    - pri otvaranju datoteke adresar se prenosi u OM
    - u OM ostaje do zatvaranja datoteke, kada se upisuje nazad na disk
  - elementima niza pokazivača
    - pristup na osnovu binarne vrednosti njihove pozicije u nizu
      - ta vrednost izražena je putem *d* bitova

Dinamička rasuta organizacija datoteke

- **Adresar**
  - indeksi niza pokazivača se ponekad predstavljaju kao kompletno binarno stablo
    - u čijim listovima se nalaze pokazivači ka baketima
    - levom odlaznom potegu iz jednog čvora pridružuje se binarni broj 1, a desnom 0
    - nizu dužine 2^d odgovara kompletno binarno stablo visine $h = d + 1$
    - svakom putu od korena do nekog lista odgovara $h - 1 = d$ ivica i nosi informaciju o jednom od 2^d indeksa u jednodimenzionalnom nizu pokazivača

Dinamička rasuta organizacija datoteke

- Adresar - primer
  - binarno stablo, $d = 2$, koje reprezentuje niz pokazivača dužine $2^d = 4$

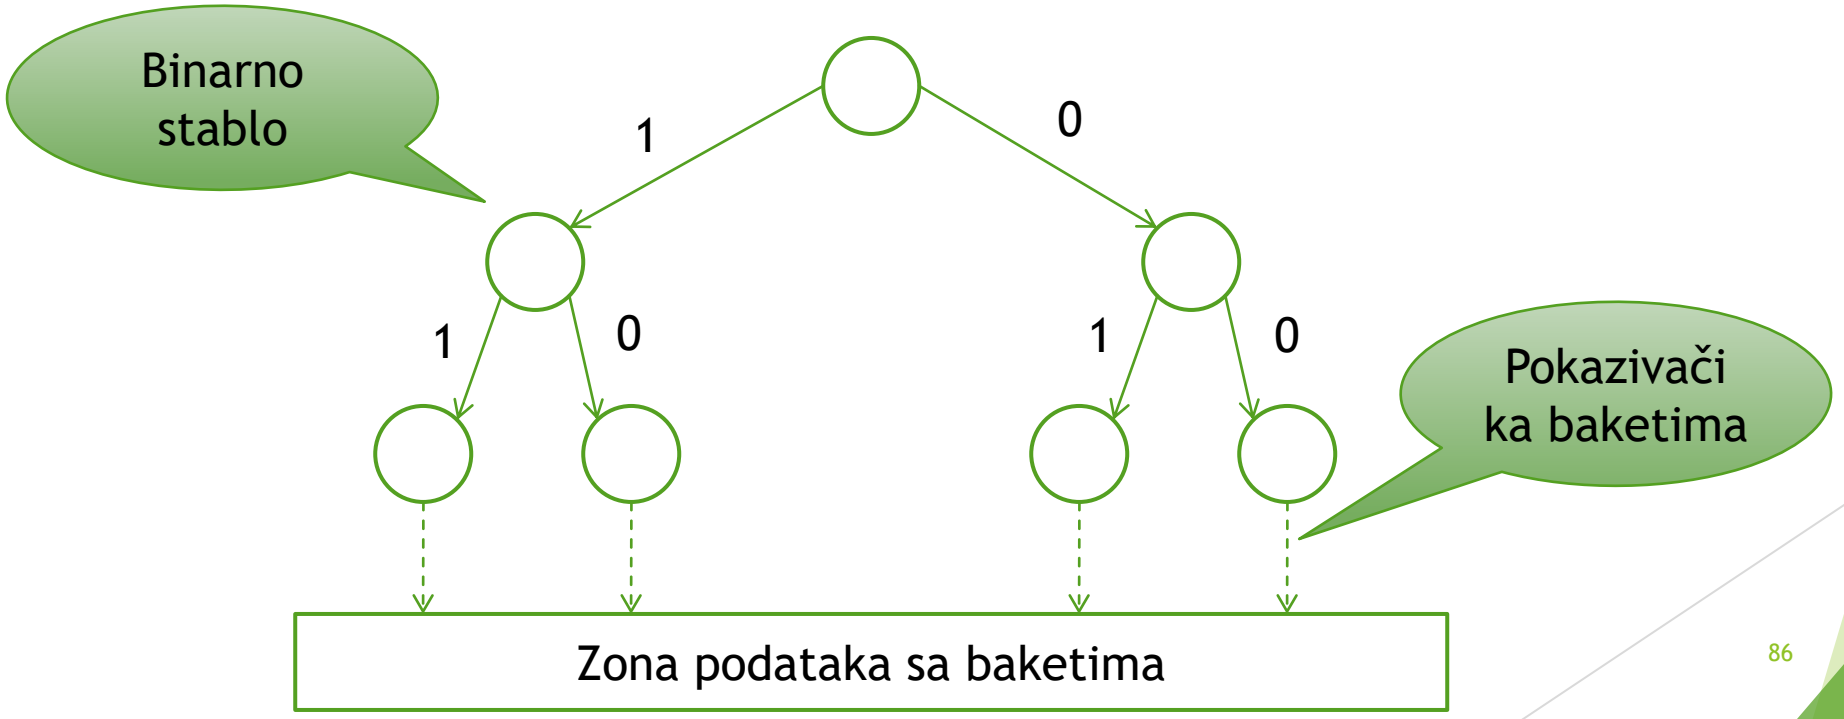

Dinamička rasuta organizacija datoteke

- **Veza između adresara i zone podataka**
  - zona podataka sadrži bakete
    - svaki sadrži najviše *b* slogova
    - svaki sadrži zaglavlje sa poljima *d'* i *m*
    - svi slogovi u baketu moraju imati istih samo prvih *d'* bitova vrednosti transformacije
    - svaki element niza pokazivača u adresaru ukazuje na jedan baket koji poseduje slogove sa istih *d'* vodećih bitova vrednosti transformacije *vt*

Dinamička rasuta organizacija datoteke

- **Veza između adresara i zone podataka**
  - ako za neki baket važi $d = d'$
    - svi slogovi u baketu imaju iste vrednosti transformacije *vt* dužine *d*
    - samo jedan pokazivač vodi od niza pokazivača u adresaru ka baketu
    - za $d > 0$ vrednosti transformacije *vt* slogova u baketu su jednake onoj vrednosti transformacije koja predstavlja indeks pokazivača ka baketu *i*
    - za $d = d' = 0$ vrednosti transformacije slogova u baketu su nebitne, a niz pokazivača je jednočlan
  - pošto broj pokazivača adresara koji ukazuju na isti baket iznosi $2^{d-d'}$, ako za neki baket važi $d' < d$ tada
    - slogovi u baketu moraju imati istih d' bitova najveće težine za *vt*, a mogu imati neke od $d - d'$ bitova najmanje težine različite
    - $2^{d-d'}$ susednih pokazivača čiji indeksi imaju istih d' bitova najveće težine za *vt*, ukazuje ka posmatranom baketu

Dinamička rasuta organizacija datoteke

- Predstava dinamičke rasute datoteke

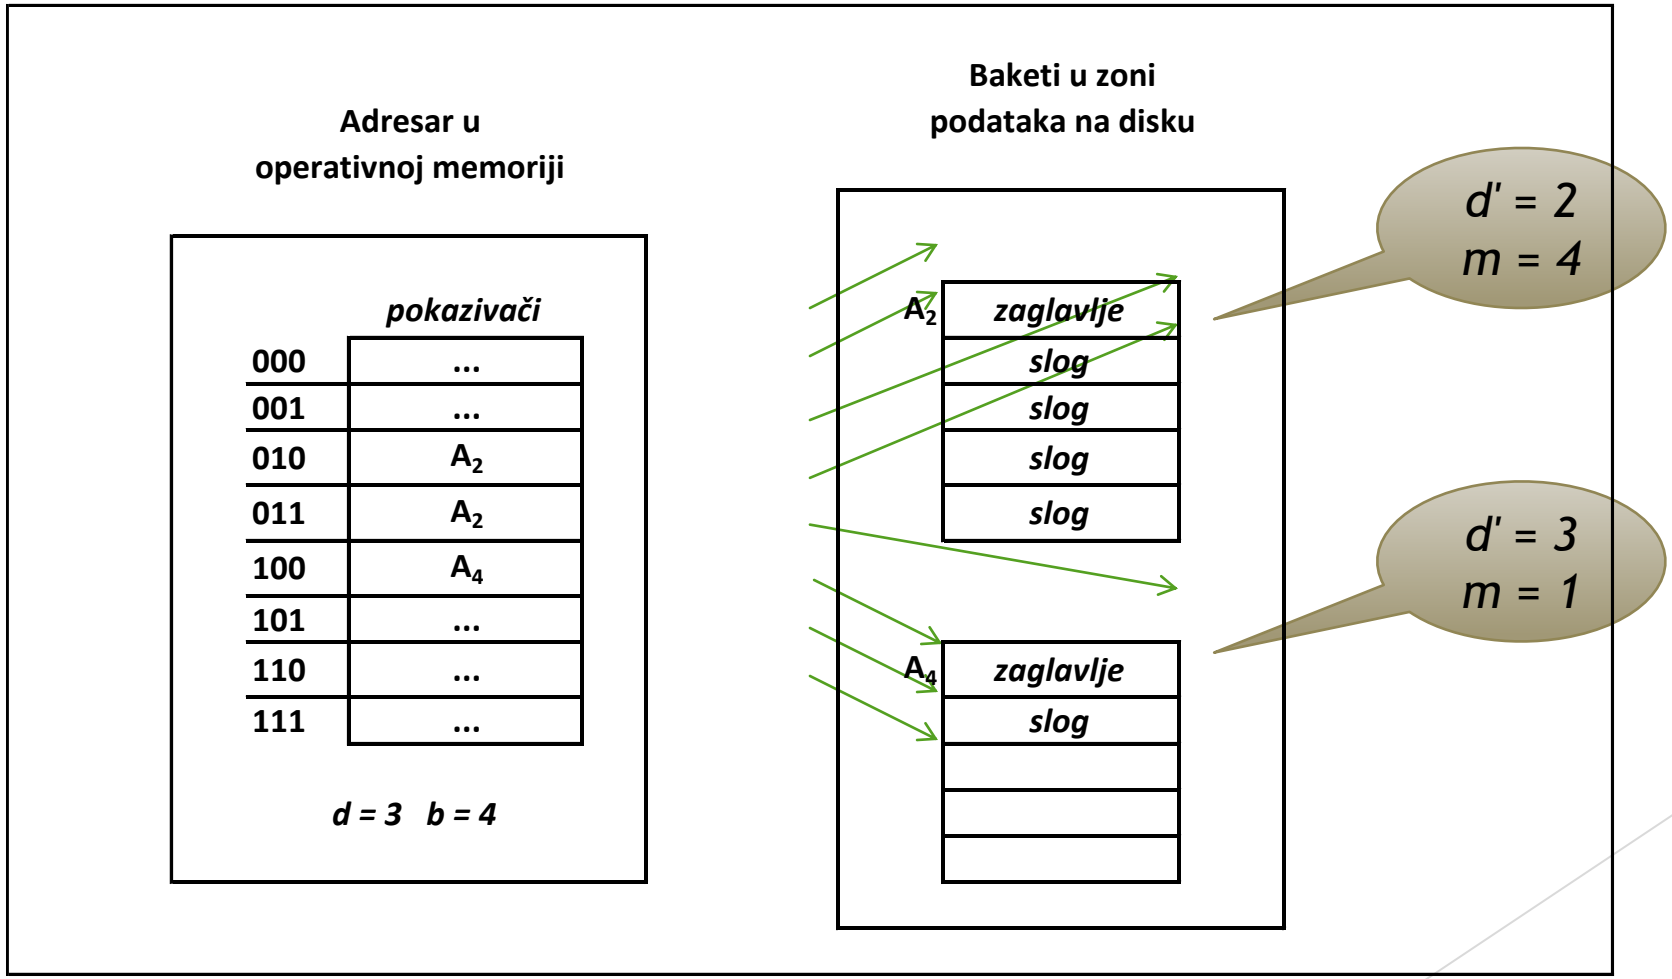

Dinamička rasuta organizacija datoteke

- **Generisanje vrednosti transformacije**
  - kako bi se izbeglo snižavanje poželjnog stepena slučajnosti transformacije
    - vrednosti ključa *k* se podvrgavaju netrivijalnoj transformaciji
    - redosled binarnih pozicija rezultata transformacije *h*(*k*) se invertuje
  - za transformaciju *h* se bira neka metoda generisanja pseudoslučajnih brojeva
    - čiji je cilj da od datih vrednosti ključa sloga proizvede niz vrednosti sa što ravnomernijom raspodelom
    - pojava više od *b* slogova sinonima u okviru jedne klase može dovesti do potrebe da se menja metoda transformacije jer
    - dinamičke rasute datoteke ne poseduju mehanizam za smeštaj prekoračilaca

Dinamička rasuta organizacija datoteke

- **Formiranje dinamičke rasute datoteke**
  - u režimu direktne obrade
    - vrednosti ključa slogova ulazne serijske datoteke podvrgavaju se transformaciji
    - od rezultata koristi se *d* bitova najveće težine kao indeks u jednodimenzionalnom nizu pokazivača ka baketima
    - baket čija je adresa dobijena korišćenjem tog niza u adresaru prenosi se u OM
    - ako slog sa istom vrednošću ključa u baketu ne postoji, novi slog se upisuje u baket
    - svakom upisu prethodi neuspešno traženje

Dinamička rasuta organizacija datoteke

- **Formiranje dinamičke rasute datoteke**
  - tri slučaja upisa
    - prost upis
      - izvršava se u baketu sa $m < b$ slogova
      - novi slog se upisuje u prvi slobodnu lokaciju u baketu
      - broj zauzetih lokacija m se povećava za jedan
    - upis koji dovodi do deljenja baketa i udvostručavanja dužine niza pokazivača u adresaru
      - ako važi sledeće: $m = b$, $d' = d$
    - upis koji dovodi samo do deljenja baketa
      - ako važi sledeće: $m = b$, $d' < d$

Dinamička rasuta organizacija datoteke

- **Traženje sloga u dinamičkoj rasutoj datoteci**
  - traženje logički narednog i slučajno odabranog sloga vrši se korišćenjem istog algoritma
  - koraci algoritma za traženje slučajno odabranog sloga
    - vrednost ključa *k* se podvrgava transformaciji *h*
    - rezultat transformacije *h*(*k*) se pretvara u vrednost transformacije dužine d_{max} bita
    - korišćenjem vrednosti transformacije dužine $d \leq d_{max}$ u adresaru se pronalazi adresa baketa, u kojem bi traženi slog trebalo da bude
    - ako je traženi slog u baketu, traženje je uspešno, inače je neuspešno

Dinamička rasuta organizacija datoteke

- **Traženje sloga u dinamičkoj rasutoj datoteci**
  - transformacija kluča i generisanje vrednosti
    - vrši se u OM, ne zahteva pristup disku
  - kompletan adresar nalazi u OM
    - ne zahteva pristup disku
  - jedini pristup disku u cilju čitanja baketa
  - potrebno je najviše $R = 1$ pristupa
    - ako se baket već nalazi u OM važi $R = 0$

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - u režimu direktne obrade
    - svakom upisu ili brisanju prethodi jedno traženje
  - **upis novog sloga**
    - vrši po principima upisa novih slogova pri formiranju datoteke
    - u najnepovoljnijem slučaju upis zahteva
      - dva pristupa datoteci, ako upis ne dovodi do prepunjenja baketa
        - jedan pristup za neuspešno traženje
        - drugi za upis baketa
      - tri pristupa datoteci, ako upis dovodi do prepunjenja baketa
        - jedan pristup za neuspešno traženje
        - drugi i treći pristup za upis polaznog i jednog novog baketa u datoteku
    - broj pristupa (najnepovoljniji slučaj): $2 \leq R_i \leq 3$

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - **brisanje postojećih slogova**
    - dva baketa su prijatelji ako zadovoljavaju uslove
      - na njih ukazuju dva takva pokazivača u adresaru čiji se indeksi razlikuju samo na poziciji najmanje težine
      - za oba baketa važi $d' = d$
      - važi $d > 0$

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - **tri slučaja brisanja**
    - prosto brisanje
      - u baketu sa m > 1 slogova za koji važi da je ukupan broj njegovih slogova i slogova njegovog prijatelja veći od *b*
      - nakon uspešnog traženja svi slogovi u baketu koji su smešteni iza sloga koji se briše,
        - pomeraju se za jednu poziciju ulevo
        - parametar *m* se smanjuje za jedan
      - poslednji slog u baketu se briše
        - smanjivanjem parametra *m* za jedan
        - nakon čega se mora učitati prijatelj baket da bi se proverio ukupni broj slogova u ta dva baketa

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - **tri slučaja brisanja**
    - spajanje susednih baketa, bez uticaja na veličinu adresara
      - dešava se kada nakon brisanja sloga ukupan broj slogova u dva baketa prijatelja nije veći od b
      - baketi prijatelji se spajaju
      - u spojenom baketu lokalna vrednost transformacije postaje $d' = d' - 1$
      - parametar m u baketu dobijenom spajanjem postaje $m \leq b$
      - svi elementi niza pokazivača koji su ukazivali na bakete prijatelje pre spajanja dobijaju pokazivač ka baketu dobijenom spajanjem

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - **tri slučaja brisanja**
    - spajanje susednih baketa sa smanjenjem dužine niza pokazivača na pola
      - dešava se kada na svaki baket ukazuju najmanje po dva pokazivača u adresaru
      - u adresaru se vrednost transformacije *d* umanjuje za jedan
        - čime se dužina niza pokazivača smanjuje na pola
      - svaka dva pokazivača čiji se indeksi razlikuju samo na binarnoj poziciji najmanje težine transformišu se u jedan

Dinamička rasuta organizacija datoteke

- **Ažuriranje dinamičke rasute datoteke**
  - **brisanje**
    - pod pretpostavkom da datoteka sadrži bar dva baketa, i u slučaju prostog i u slučaju brisanja sa spajanjem susednih baketa, u najnepovoljnijem slučaju je potrebno izvršiti tri pristupa datoteci
      - jedan za pronalaženje sloga
      - jedan za učitavanje susednog baketa
      - jedan za upis bilo ažuriranog polaznog baketa ili baketa dobijenog spajanjem
    - broj pristupa: $R_d = 3$
    - redukcija veličine adresara ne zahteva pristupe disku

Dinamička rasuta organizacija datoteke

- **Obrada dinamičke rasute datoteke**
  - dinamičke (kao i statičke) rasute datoteke su nepogodne za korišćenje u ulozi osnovne vodeće datoteke
  - mogu se koristiti kao obrađivane i vodeće u režimu direktne obrade
  - ne mogu se koristiti kao vodeće u režimu redosledne obrade
    - pošto im fizička struktura ne sadrži podatke o logičkoj strukturi podataka

Dinamička rasuta organizacija datoteke

- **Obrada dinamičke rasute datoteke**
  - mogu se obrađivati i u režimu redosledne i u režimu direktne obrade
    - iste su performanse redosledne i direktne obrade rasute datoteke
      - zbog iste efikasnosti traženja i logički narednog i slučajno odabranog sloga
      - pod pretpostavkom da se adresar može smestiti u OM
        broj pristupa za pronalaženje jednog sloga: $R = 1$
    - ukupni broj pristupa

$$R_{uk} = N_v^u + N_v^n$$

      - važi i pri redoslednoj i pri direktnoj obradi
      - ako je broj slogova vodeće datoteke

$$N_v = N_v^u + N_v^n$$

Dinamička rasuta organizacija datoteke

- **Ocena karakteristika i oblasti primene**
  - ne proizvodi slogove prekoračioce
  - datoteka se širi i skuplja u zavisnosti od broja aktuelnih slogova
  - broj pristupa pri traženju ne zavisi od veličine datoteke
    - ako se adresar može kompletan smestiti u OM, tada je broj pristupa i u najnepovoljnijem slučaju 1
    - zato su ove datoteke veoma pogodne za direktnu obradu
  - nisu pogodne za redoslednu obradu
    - ali broj pristupa za pronalaženje jednog logički narednog sloga u obrađivanoj rasutoj datoteci iznosi jedan

Dinamička rasuta organizacija datoteke

- **Ocena karakteristika i oblasti primene**
  - zauzeće memorijskog prostora na disku
    - očekivani broj baketa

$$\overline{B} \approx \frac{N}{b \ln 2}$$

      - *N* – broj slogova
      - *b* – faktor blokiranja

Dinamička rasuta organizacija datoteke

- **Ocena karakteristika i oblasti primene**
  - rasute datoteke sa dinamičkom transformacijom
    - zasnovane su na ideji deljenja baketa, koju su pozajmile od *B*-stabala
      - u traženju slučajno odabranog sloga su efikasnije od *B*-stabala
    - popularnost ovih vrsta datoteka zaostaje za *B*-stablima
    - postoje SUBP-ovi
      - koji podržavaju korišćenje fizičkih struktura zasnovanih na principima dinamičkih rasutih datoteka
      - podrazumevaju korišćenje *B*-stabala dok se izgradnja rasutih struktura mora posebno zahtevati

Sadržaj

- Rasute organizacije datoteka
- Direktna i relativna organizacija datoteke
- Statička rasuta organizacija datoteke
- Dinamička rasuta organizacija datoteke

Pitanja i komentari

acs
applied computer science

UNIVERZITET U NOVOM SADU
FAKULTET TEHNIČKIH NAUKA
KATEDRA ZA PRIMENJENE RAČUNARSKE NAUKE

DAIS
Data Science and
Information Systems Group

Kraj prezentacije

Rasuta organizacija datoteke

Usluge metoda pristupa i vrste organizacija datoteka

Baze podataka 1 - Informacioni inženjering